31 | 新一代流处理框架：Batch mode和Continuous mode哪家强？

2021-11-22 吴磊

《零基础入门Spark》 课程介绍 >

讲述：吴磊
时长 15:15 大小 13.97M

你好，我是吴磊。

在上一讲，我们通过“流动的 Word Count”示例，初步结识了 Structured Streaming，并学习了流处理开发三要素，也就是 Source、流处理引擎与 Sink。

极客时间

今天这一讲，让我们把目光集中到 Structured Streaming，也就是流处理引擎本身。Structured Streaming 与 Spark MLlib 并列，是 Spark 重要的子框架之一。值得一提的是，Structured Streaming 天然能够享受 Spark SQL 提供的处理能力与执行性能，同时也能与其他子框架无缝衔接。因此，基于 Structured Streaming 这个新一代框架开发的流处理应用，天然具备优良的执行性能与良好的扩展性。

知己知彼，百战百胜。想要灵活应对不同的实时计算需求，我们就要先了解 Structured Streaming 的计算模型长啥样，搞清楚它如何应对容错、保持数据一致性。我们先从计算模型说起。

计算模型

当数据像水流一样，源源不断地流进 Structured Streaming 引擎的时候，引擎并不会自动地依次消费并处理这些数据，它需要一种叫做 Trigger 的机制，来触发数据在引擎中的计算。

换句话说，Trigger 机制，决定了引擎在什么时候、以怎样的方式和频率去处理接收到的数据流。Structured Streaming 支持 4 种 Trigger，如下表所示。

Trigger类型	计算模型	API示例	含义
Default	Batch mode	N/A	默认Trigger，自然切割
Fixed interval		writeStream.trigger(processingTime = "5 seconds")	按照固定间隔，切割数据流
One-time		writeStream.trigger(once = True)	一次性处理所有数据流
Fixed checkpoint	Continuous mode	writeStream.trigger(continuous = "1 second")	连续地、逐条处理数据流

极客时间

Structured Streaming支持的4种Trigger

要为流处理设置 Trigger，我们只需基于 writeStream API，调用 trigger 函数即可。Trigger 的种类比较多，一下子深入细节，容易让你难以把握重点，所以现在你只需要知道 Structured Streaming 支持种类繁多的 Trigger 即可。

我们先把注意力，放在计算模型上面。对于流数据，Structured Streaming 支持两种计算模型，分别是 Batch mode 和 Continuous mode。**所谓计算模型，本质上，它要解决的问题，就是 Spark 以怎样的方式，来对待并处理流数据。**

这是什么意思呢？没有对比就没有鉴别，咱们不妨通过对比讲解 Batch mode 和 Continuous mode，来深入理解计算模型的含义。

Batch mode

我们先来说说 Batch mode，所谓 Batch mode，它指的是 Spark 将连续的数据流，切割为离散的数据微批（Micro-batch），也即小份的数据集。

形象一点说，Batch mode 就像是“抽刀断水”，两刀之间的水量，就是一个 Micro-batch。而每一份 Micro-batch，都会触发一个 Spark Job，每一个 Job 会包含若干个 Tasks。学习过基础知识与 Spark SQL 模块之后，我们知道，这些 Tasks 最终会交由 Spark SQL 与 Spark Core 去做优化与执行。

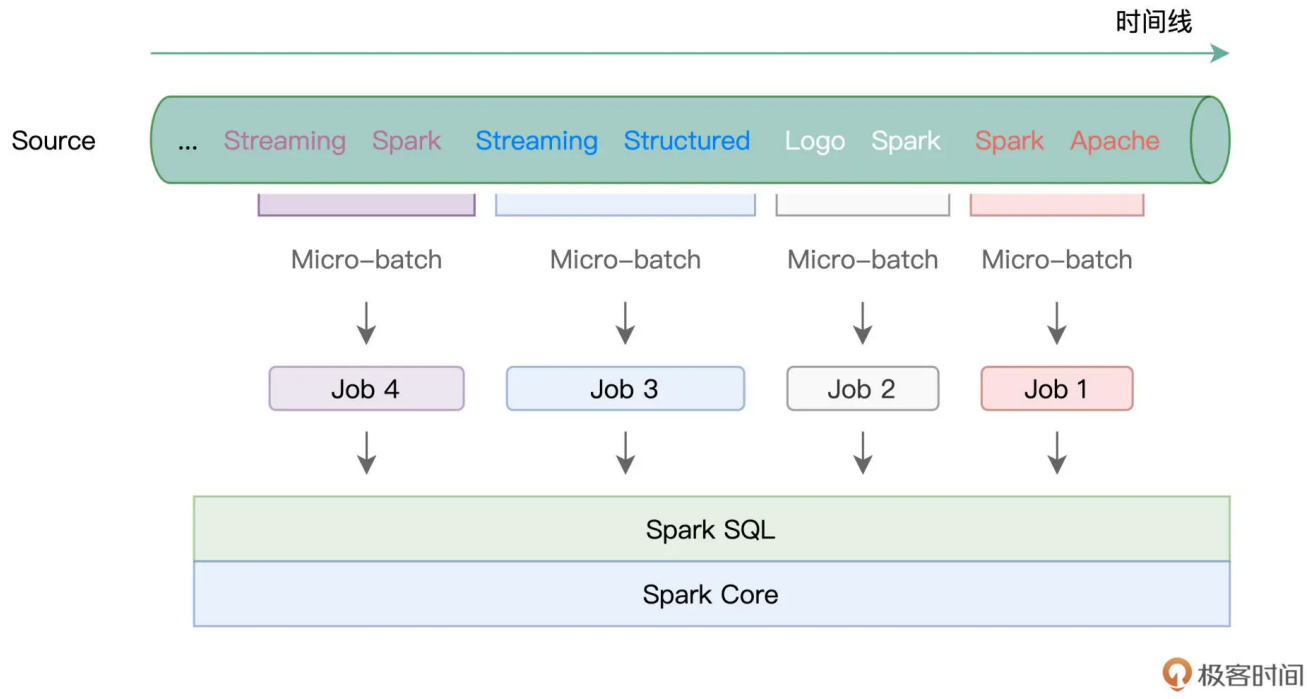

计算模型：Batch mode

在这样的计算模型下，不同种类的 Trigger，如 Default、Fixed interval 以及 One-time，无非是在以不同的方式控制 Micro-batch 切割的粒度罢了。

比方说，在 Default Trigger 下，Spark 会根据数据流的流入速率，自行决定切割粒度，无需开发者关心。而如果开发者想要对切割粒度进行人为的干预，则可以使用 Fixed interval Trigger，来明确定义 Micro-batch 切割的时间周期。例如，Trigger.ProcessingTime(“5 seconds”)，表示的是，每隔 5 秒钟，切割一个 Micro-batch。

Continuous mode

与 Batch mode 不同，Continuous mode 并不切割数据流，而是以事件 / 消息（Event / Message）为粒度，用连续的方式来处理数据。这里的事件或是消息，指代的是原始数据流中最细粒度的数据形式，它可以是一个单词、一行文本，或是一个画面帧。

以“流动的 Word Count”为例，Source 中的事件 / 消息就是一个个英文单词。说到这里，你可能会有疑问：“在 Batch mode 下，Structured Streaming 不也是连续地创建 Micro-batch 吗？数据同样是不丢不漏，Continuous mode 与 Batch mode 有什么本质上的区别吗？”

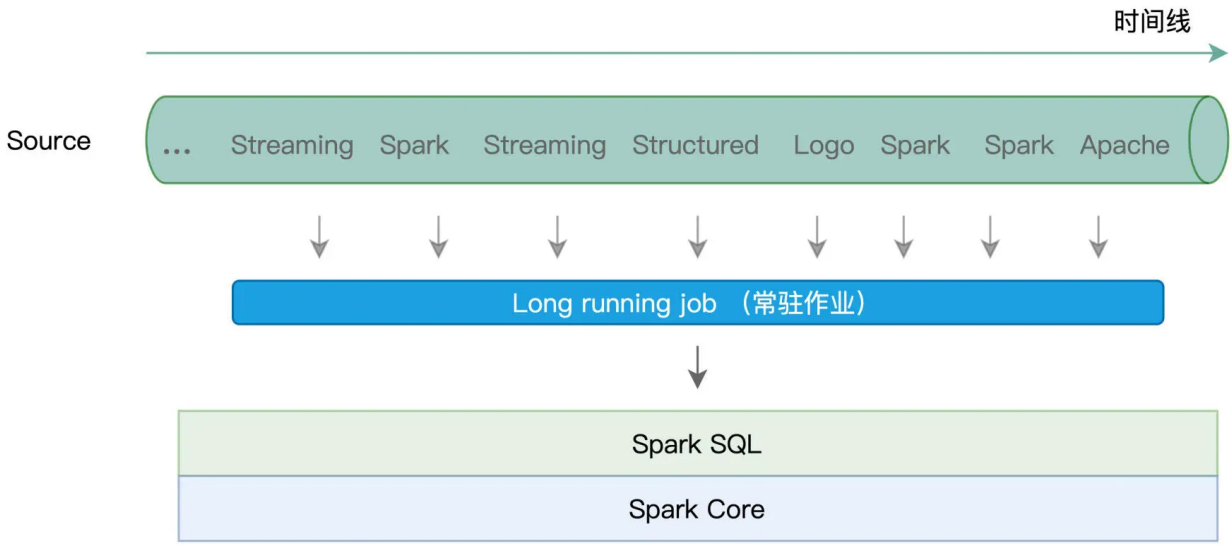

计算模型：Continuous mode

一图胜千言，对比两种计算模型的示意图，我们可以轻松地发现它们之间的差异所在。在 Continuous mode 下，Structured Streaming 使用一个常驻作业（Long running job）来处理数据流（或者说服务）中的每一条消息。

那么问题来了，相比每个 Micro-batch 触发一个作业，Continuous mode 选择采用常驻作业来进行服务，有什么特别的收益吗？或者换句话说，这两种不同的计算模型，各自都有哪些优劣势呢？

用一句话来概括，**Batch mode 吞吐量大、延迟高（秒级），而 Continuous mode 吞吐量低、延迟也更低（毫秒级）**。吞吐量指的是单位时间引擎处理的消息数量，批量数据能够更好地利用 Spark 分布式计算引擎的优势，因此 Batch mode 在吞吐量自然更胜一筹。

而要回答为什么 Continuous mode 能够在延迟方面表现得更加出色，我们还得从 Structured Streaming 的容错机制说起。

容错机制

对于任何一个流处理引擎来说，容错都是一项必备的能力。所谓容错，它指的是，在计算过程中出现错误（作业层面、或是任务层面，等等）的时候，流处理引擎有能力恢复被中断的计算过程，同时保证数据上的不重不漏，也即保证数据处理的一致性。

从数据一致性的角度出发，这种容错的能力，可以划分为 3 种水平：

At most once：最多交付一次，数据存在丢失的风险；

At least once：最少交付一次，数据存在重复的可能；

Exactly once：交付且仅交付一次，数据不重不漏。

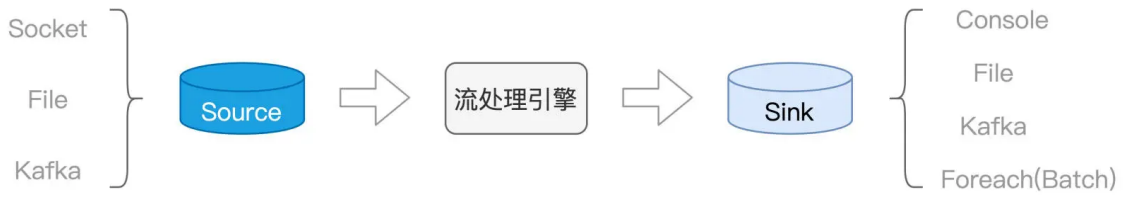

极客时间

流处理3要素

这里的交付，指的是数据从 Source 到 Sink 的整个过程。对于同一条数据，它可能会被引擎处理一次或（在有作业或是任务失败的情况下）多次，但根据容错能力的不同，计算结果最终可能会交付给 Sink 零次、一次或是多次。

聊完基本的容错概念之后，我们再说回 Structured Streaming。就 Structured Streaming 的容错能力来说，Spark 社区官方的说法是：“结合幂等的 Sink，Structured Streaming 能够提供 Exactly once 的容错能力”。

实际上，这句话应该拆解为两部分。在数据处理上，结合容错机制，Structured Streaming 本身能够提供“At least once”的处理能力。而结合幂等的 Sink，Structured Streaming 可以实现端到端的“Exactly once”容错水平。

比方说，应用广泛的 Kafka，在 Producer 级别提供跨会话、跨分区的幂等性。结合 Kafka 这样的 Sink，在端到端的处理过程中，Structured Streaming 可以实现“Exactly once”，保证数据的不重不漏。

不过，在 Structured Streaming 自身的容错机制中，为了在数据处理上做到“At least once”，Batch mode 与 Continuous mode 这两种不同的计算模型，分别采用了不同的实现方式。而容错实现的不同，正是导致两种计算模型在延迟方面差异巨大的重要因素之一。

接下来，我们就来说一说，Batch mode 与 Continuous mode 分别如何做容错。

Batch mode 容错

在 Batch mode 下，Structured Streaming 利用 Checkpoint 机制来实现容错。在实际处理数据流中的 Micro-batch 之前，Checkpoint 机制会把该 Micro-batch 的元信息全部存储到开发者指定的文件系统路径，比如 HDFS 或是 Amazon S3。这样一来，当出现作业或是任务失败时，引擎只需要读取这些事先记录好的元信息，就可以恢复数据流的“断点续传”。

要指定 Checkpoint 目录，只需要在 writeStream API 的 option 选项中配置 checkpointLocation 即可。我们以上一讲的“流动的 Word Count”为例，代码只需要

做如下修改即可。

```
df.writeStream
// 指定Sink为终端（Console）
.format("console")

// 指定输出选项
.option("truncate", false)

// 指定Checkpoint存储地址
.option("checkpointLocation", "path/to/HDFS")

// 指定输出模式
.outputMode("complete")
//.outputMode("update")

// 启动流处理应用
.start()
// 等待中断指令
.awaitTermination()
```

在 Checkpoint 存储目录下，有几个子目录，分别是 offsets、sources、commits 和 state，它们所存储的内容，就是各个 Micro-batch 的元信息日志。对于不同子目录所记录的实际内容，我把它们整理到了下面的图解中，供你随时参考。

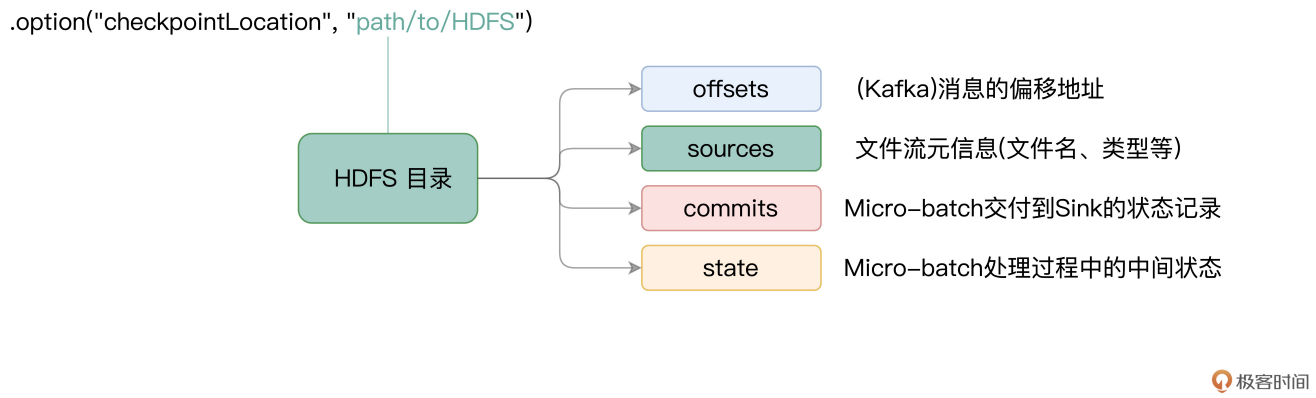

Checkpoint与WAL日志

对于每一个 Micro-batch 来说，在它被 Structured Streaming 引擎实际处理之前，Checkpoint 机制会先把它的元信息记录到日志文件，因此，这些日志文件又被称为 Write Ahead Log（WAL 日志）。

换句话说，当源数据流进 Source 之后，它需要先到 Checkpoint 目录下进行“报道”，然后才会被 Structured Streaming 引擎处理。毫无疑问，“报道”这一步耽搁了端到端的处理延迟，如下图所示。

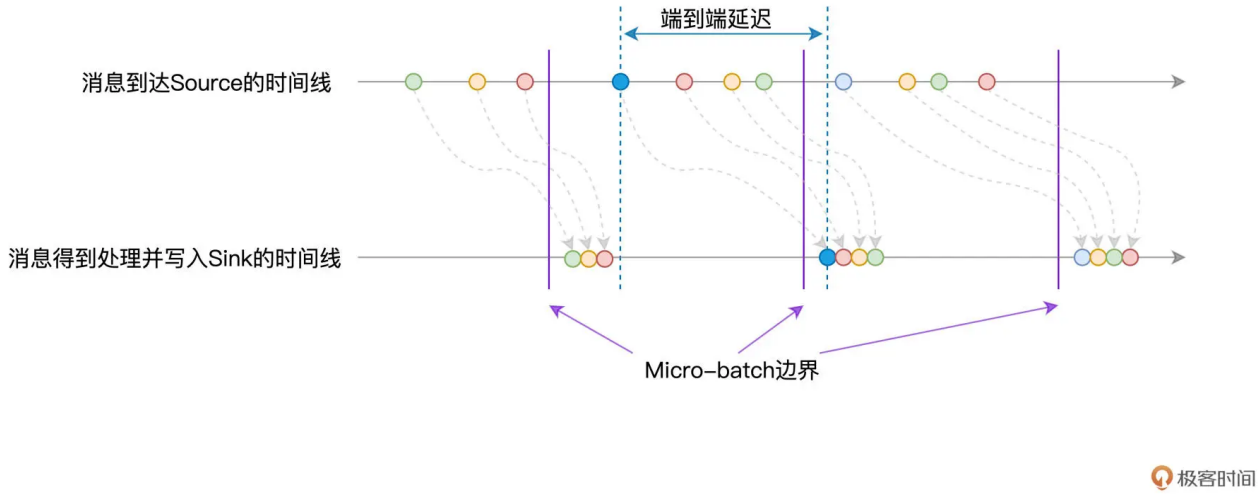

Batch mode下端到端延迟示意图

除此之外，由于每个 Micro-batch 都会触发一个 Spark 作业，我们知道，作业与任务的频繁调度会引入计算开销，因此也会带来不同程度的延迟。在运行模式与容错机制的双重加持下，Batch mode 的延迟水平往往维持在秒这个量级，在最好的情况下能达到几百毫秒左右。

Continuous mode 容错

相比 Batch mode，Continuous mode 下的容错没那么复杂。在 Continuous mode 下，Structured Streaming 利用 Epoch Marker 机制，来实现容错。

因为 Continuous mode 天然没有微批，所以不会涉及到微批中的延迟，到达 Source 中的消息可以立即被 Structured Streaming 引擎消费并处理。但这同时也带来一个问题，那就是引擎如何把当前的处理进度做持久化，从而为失败重试提供可能。

为了解决这个问题，Spark 引入了 Epoch Marker 机制。所谓 Epoch Marker，你可以把它理解成是水流中的“游标”，这些“游标”随着水流一起流动。每个游标都是一个 Epoch Marker，而游标与游标之间的水量，就是一个 Epoch，开发者可以通过如下语句来指定 Epoch 间隔。

```
writeStream.trigger(continuous = "1 second")
```

复制代码

以表格中的代码为例，对于 Source 中的数据流，Structured Streaming 每隔 1 秒，就会安插一个 Epoch Marker，而两个 Epoch Marker 之间的数据，就称为一个 Epoch。你可能会问：“Epoch Marker 的概念倒是不难理解，不过它有什么用呢？”

在引擎处理并交付数据的过程中，每当遇到 Epoch Marker 的时候，引擎都会把对应 Epoch 中最后一条消息的 Offset 写入日志，从而实现容错。需要指出的是，日志的写入是异步的，因此这个过程不会对数据的处理造成延迟。

有意思的是，对于这个日志的称呼，网上往往也把它叫作 Write Ahead Log。不过我觉得这么叫可能不太妥当，原因在于，准备写入日志的消息，都已经被引擎消费并处理过了。Batch mode 会先写日志、后处理数据，而 Continuous mode 不一样，它是先处理数据、然后再写日志。所以，把 Continuous mode 的日志称作是“Write After Log”，也许更合适一些。

我们还是用对比的方法来加深理解，接下来，我们同样通过消息到达 Source 与 Structured Streaming 引擎的时间线，来示意 Continuous mode 下的处理延迟。

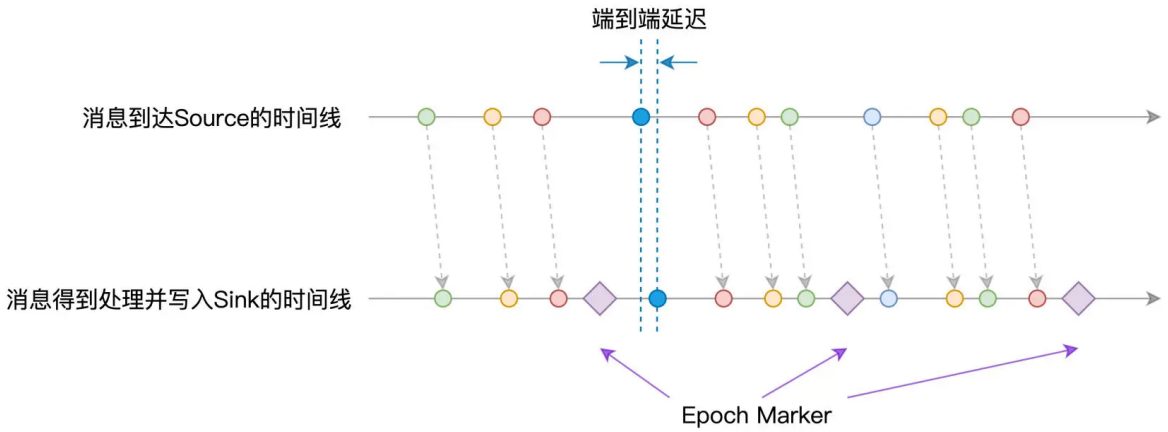

Continuous mode下端到端延迟示意图

可以看到，消息从 Source 产生之后，可以立即被 Structured Streaming 引擎消费并处理，因而在延迟性方面，能够得到更好的保障。而 Epoch Marker 则会帮助引擎识别当前最新处理的消息，从而把相应的 Offset 记录到日志中，以备失败重试。

重点回顾

到此为止，今天的内容就全部讲完了，我们一起来做个总结。

今天这一讲，我们学习了 Structured Streaming 中两种不同的计算模型——Batch mode 与 Continuous mode。只有了解了它们各自在吞吐量、延迟性和容错等方面的特点，在面对日常工作中不同的流计算场景时，我们才能更好地做出选择。

在 Batch mode 下，Structured Streaming 会将数据流切割为一个个的 Micro-batch。对于每一个 Micro-batch，引擎都会创建一个与之对应的作业，并将作业交付给 Spark SQL 与 Spark Core 付诸优化与执行。

Batch mode 的特点是吞吐量大，但是端到端的延迟也比较高，延迟往往维持在秒的量级。Batch mode 的高延迟，一方面来自作业调度本身，一方面来自它的容错机制，也就是 Checkpoint 机制需要预写 WAL（Write Ahead Log）日志。

要想获得更低的处理延迟，你可以采用 Structured Streaming 的 Continuous mode 计算模型。在 Continuous mode 下，引擎会创建一个 Long running job，来负责消费并服务来自 Source 的所有消息。

在这种情况下，Continuous mode 天然地避开了频繁生成、调度作业而引入的计算开销。与此同时，利用 Epoch Marker，通过先处理数据、后记录日志的方式，Continuous mode 进一步消除了容错带来的延迟影响。

尺有所短、寸有所长，Batch mode 在吞吐量上更胜一筹，而 Continuous mode 在延迟性方面则能达到毫秒级。

不过，需要特别指出的是，到目前为止，在 Continuous mode 下，Structured Streaming 仅支持非聚合（Aggregation）类操作，比如 map、filter、flatMap，等等。而**聚合类的操作，比如“流动的 Word Count”中的分组计数，Continuous mode 暂时是不支持的，这一点难免会限制 Continuous mode 的应用范围，需要你特别注意。**

每课一练

Batch mode 通过预写 WAL 日志来实现容错，请你脑洞一下，有没有可能参考 Continuous mode 中先处理数据、后记录日志的方式，把 Batch mode 中写日志的动作，也挪到数据消费与处理之后呢？

欢迎你在留言区跟我交流讨论，也推荐你把这一讲的内容分享给更多朋友。

分享给需要的人，Ta订阅后你可得 20 元现金奖励

生成海报并分享

赞 1 提建议

© 版权归极客邦科技所有，未经许可不得传播售卖。 页面已增加防盗追踪，如有侵权极客邦将依法追究其法律责任。

上一篇 30 | Structured Streaming：从"流动的Word Count"开始

下一篇 32 | Window操作&Watermark：流处理引擎提供了哪些优秀机制？

更多学习推荐

精选留言 (5)

写留言

刘启涛
2021-12-02

课后习题:
我觉得先消费再记录的方式是可以实现，但是如果记录的时候出现异常(hdfs写数据网络抖动)，可能会导致数据重复消费，这种方式"Exactly Once"的准确性没有先记录、再消费数据高。
老师，我这里还有一个问题，Continuous mode是处理完数据异步记录日志，感觉很难保...
展开

作者回复: 老弟思考的很到位~

从实现上来说，先消费再记录的方式，肯定是可以实现的。不过这样一来，会有几方面的问题：
1）首先是老弟提到的，数据处理失败，就存在一个重试的问题，如果是先写WAL（数据+元数据），再消费，因为数据已经落盘（本地或是HDFS）缓存了，因此再消费一遍，很容易，也很方便。但如果反过来，先消费、再写日志，那就得从Source重新拉数据，网络开销是一方面，再者，为了确保拉取的是同一份数据，实际上也需要维护元数据，来管理offsets
2）再一个，即便是没有失败重试的问题，在batch mode下，一个批次的数据，还是以批次为粒度，来触发一个job，这中间的任务调度延迟，其实仅靠先处理数据，是去不掉的。这个跟Continuous mode很不一样，Continuous mode是常驻的job，因此不存在这个问题。

关于老弟说的"Exactly once"，严格来说，Spark自己不能保证"Exactly once"，但它可以做到"At least once"，再结合幂等的Sink，端到端可以做到"Exactly once"。但是就Structured Streaming来说，它自己只能做到"At least once"。

六月的余晖
2021-11-22

老师，可以比较一下Continuous mode和Flink 吗
展开

作者回复: 好问题，先说结论，虽然咱们的主题是Spark，不过就追求实时性的流处理来说，我还是会推荐Flink。

Flink的Kappa架构，天然对流处理友好，尤其是对于实时性的支持。因为出发点就是流计算，因此随着Flink的发展、迭代，开发API也越来越丰富，功能也越来越完善。

而Spark不同，Spark实际上是Lambda架构，天然以批处理为导向，最初的流处理，也是微批模式，也就是Micro-batch，咱们分析了，微批模式，没法保证实时性，不过对于高吞吐，倒是比较友好。尽管Spark官方推出了Continuous mode，但是目前功能、API各方面还没有那么完善，至少现在为止，Continuous mode还不支持聚合操作，仅这一点，限制就太大了，试问现在的数据处

理，有多少逻辑是不需要聚合操作的呢？太少了。因此，Continuous mode，在我看来，更多的是一种尝试和探索，至于后续能否提供更多的功能与能力，还要看Spark社区对于这方面的发力。

不过，从课程内容的角度，我们还是得让大家知道，Spark社区推出了这么一种Continuous mode。一方面是让大家知道有这么回事，再者和Micro batch mode是个对比，有利于大家做对比学习，加深印象

但是就能力来说，从实时性和功能完善的角度出发， 我觉得，还是Flink更加实用

Geek_995b78

2021-11-22

老师，后面课程没有spark streaming内容的讲解吗

展开

作者回复: 课程主要围绕Structure Streaming哈

Geek_995b78

2021-11-22

老师，虽然kafka幂等性不能保证跨分区的原子写入，但是kafka还支持事务呀

作者回复: 感谢老弟提醒，上一个留言，一起回复了哈~

Geek_995b78

2021-11-22

老师，0.11版本后的kafka，引入了幂等性机制呀，文中问什么说kafka不是幂等的呢

作者回复: 感谢老弟的提醒，原文的描述确实有问题~ 新版本的Kafka确实在Producer级别支持幂等和事务性，结合transactional id + PID + sequence number，能做到跨会话、跨Topic Partition做到幂等。再结合Structured Streaming对于Event time、Late Data和Watermark的支持，以及WAL和Checkpoint机制，理论上，Structured Streaming + Kafka确实可以做到Exactly once。

原文的表述有误，当时脑子里想的是老的Spark Streaming，由于不支持事件时间，仅支持Processing time，而一般的时间窗口，都会有group by这些带状态的计算。因此即便是结合Kafka的幂等

性，也很难做到Exactly once的Delivery。

再次感谢老弟，我回头抽空调整下原文的描述，谢谢~